



Grupo de Estudo de Geração Hidráulica-GGH

Análise e diagnóstico de falha em motor Brushless DC através de processamento de dados de vibração utilizando redes neurais artificiais

**VICTOR SUGUITI TANAKA(1); MATEUS GIESBRECHT(1);
UNICAMP(1);**

RESUMO

Neste informe técnico é relatada a detecção de falhas em um motor BLDC (Brushless DC) de pequeno porte através da coleta de sinais de vibrações causados pela falta de uma das fases de alimentação do motor. O diagnóstico e a classificação da falha foram realizados com uma rede neural. O classificador foi capaz de detectar a falha ocorrida com uma exatidão bastante razoável utilizando os dados de vibração radial da máquina.

PALAVRAS-CHAVE

Diagnóstico de falha, Redes Neurais, Brushless DC

1.0 - INTRODUÇÃO

Motores Brushless DC são motores de corrente contínua, que como o nome diz, não possuem escovas como no Motor DC com escovas. Essas escovas em contato com o anel comutador permitem que se altere o sentido da corrente nos enrolamentos do rotor. Desta forma, é possível obter um torque em apenas uma direção durante o movimento completo do motor. Já no motor BLDC da pesquisa, o campo magnético de excitação é criado no rotor por ímãs permanentes enquanto o estator é bobinado. Dessa maneira, para alterar o sentido da corrente de forma que o torque seja em apenas uma direção, são utilizados circuitos de disparo que operam como comutadores eletrônicos. A vantagem desse tipo de montagem é que, como não há anéis comutadores e escovas, o projeto mecânico e a manutenção do motor são simplificadas [1].

Os motores BLDC tiveram seu uso crescente nos últimos anos devido à alta eficiência, controle preciso de torque e velocidade e baixo custo de manutenção [2]. Além disso, são mais compactos e podem ter seu controle baseado em sensor de Efeito Hall, em que se monitora diretamente a posição do rotor, para que assim, seja possível saber qual bobina energizar e o sentido da corrente no enrolamento, de forma que se torne um ímã com polaridade norte ou sul, dependendo da polaridade do ímã do rotor que passa sobre a bobina. De outro modo, o controle pode se basear em tensão Back EMF, em que a passagem do ímã permanente do rotor gera uma tensão no enrolamento do estator, a qual pode ser monitorada permitindo que se conheça a posição do rotor, possibilitando o controle da energização das bobinas da mesma maneira que no controle por sensor Hall [3].

Analogamente, o estudo e diagnóstico de falhas em motores acompanhou esse crescimento devido à constante preocupação com a segurança em linhas de produção e com o fator econômico, uma vez que se a falha for detectada com antecedência e corrigida, a máquina tem maior durabilidade [4]. Logo, há vários ramos existentes de pesquisa nessa área.

Pesquisadores estudam falhas de desmagnetização em ímãs permanentes decorrentes das altas temperaturas em que a máquina trabalha, da operação constante sem troca e manutenção dos ímãs e da atuação nos pontos em que eles saturam [5]. São estudadas ainda falhas mecânicas (como corrosão, fadiga do

metal e desbalanceamento), onde a causa mais comum é o rolamento desbalanceado [6]. Além disso, há o estudo em falhas com curto-circuito entre as espiras dos enrolamentos do estator, onde a causa mais comum é a falta de isolamento entre os fios das bobinas. Esse tipo de falha corresponde a quase 21% das falhas em máquinas elétricas [7].

Os sinais mais analisados em falhas são a corrente de armadura, tensão Back EMF, torque e velocidade [4]. Na maioria dos casos, analisa-se a resposta em frequência para determinar características da falha, ou seja, é feito um estudo dos harmônicos na corrente de armadura, por exemplo. Essa observação é feita através da aplicação da Transformada Rápida de Fourier no sinal amostrado, obtendo a resposta em frequência, ou seja, um gráfico de espectro no domínio da frequência. Estudam-se os harmônicos na corrente de armadura e, em alguns casos, a forma do gráfico da velocidade e do torque [8].

Deste modo, há algumas formas de se classificar a falha. As mais aplicadas são o estudo do espectro de frequência, onde o gráfico é analisado e comparado em relação aos harmônicos de corrente e torque, ou seja, medem-se os sinais de torque e corrente e obtém-se o espectro da máquina sem falhas. Então, faz-se o mesmo procedimento para a máquina com falhas, e assim obtém-se uma comparação de ambos espectros [2]. Além disso, há a implementação de redes neurais para processar os dados obtidos e medidos, isto é, com os espectros de corrente, torque e vibração da máquina saudável, um programa utilizando Lógica Fuzzy pode aprender e comparar ambos os dados e, assim, ter base para classificar a falha [9]. Por outro lado, há ainda o estudo baseado em modelo ("Model-based"), em que sensores medem tensões, correntes e velocidades da máquina, os quais são usados como parâmetros em ensaios de determinação de resistência e indutância. Deste modo, é feito um estudo a respeito da variação dos parâmetros e da velocidade angular da máquina, analisando o tipo e a presença de falha [10].

Neste informe são descritos os resultados da detecção das falhas de alimentação de uma máquina BLDC através de dados de vibração, coletados a partir de um sensor de baixo custo. A detecção da falha é feita através da apresentação dos espectros em frequência das vibrações da máquina sem falha e sob falha para o treinamento das redes neurais para, na sequência, a rede ser usada na classificação.

2.0 – REVISÃO BIBLIOGRÁFICA

2.1 Rede Neural

As redes neurais artificiais são comumente utilizadas em sistemas multivariáveis sujeitos a interações não-lineares. A modelagem matemática de um neurônio artificial é feita de forma que somente seus aspectos principais sejam apresentados, de forma a simplificar o estudo. Seu modelo matemático é apresentado a seguir:




FIGURA 1 – Modelo matemático de um neurônio artificial

A saída do neurônio k pode ser representada pela equação:

$$y_k = f(u_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (1)$$

A rede neural artificial é gerada pela conexão entre vários neurônios artificiais. A estrutura mais utilizada é a em camadas, em que a saída de cada neurônio da camada anterior é ligada na entrada de todos os neurônios da camada posterior [9] [11] [12]. Pela equação (1), nota-se que a função de cada neurônio é aplicar uma relação não linear a uma combinação linear dos dados de entrada para definir a saída. Deste modo, a saída nada mais é do que a aplicação de uma função não linear ao resultado de uma combinação linear dos dados de entrada.

Para se classificar a falha do sistema, foi utilizado um *toolbox* do programa Matlab (Neuro-Fuzzy Designer), que implementa uma combinação de rede neural.

3.0 – METODOLOGIA

3.1 Montagem experimental

Para esta etapa do projeto, utilizou-se o motor BLDC com as seguintes características:

Tabela 1 – Dados de tensão, corrente e potência nominais do motor

Tensão nominal	36 V
Corrente nominal	10 A
Potência nominal	360 W

Foi utilizado o próprio controlador comercial do kit do motor BLDC, que é utilizado como *powertrain* de bicicletas elétricas, conforme é mostrado na Figura 2.



FIGURA 2 – Controlador comercial do motor BLDC

3.2 Medições das vibrações da máquina

Para essa parte do projeto, foi utilizada a referência [13]. Foi utilizado o acelerômetro embarcado da placa Freedom KL25Z para captar os sinais de vibrações da máquina sem falha. Foi preciso instalar o acelerômetro no eixo do motor, para que as medições fossem feitas com maior precisão. Na Figura 3, é retratada a montagem do acelerômetro e os eixos X, Y e Z, em que X e Y são eixos radiais, isto é, na direção do raio do motor, e Z é axial, ou seja, na direção do eixo do motor.




FIGURA 3 – Setup experimental para medições de vibração com o acelerômetro embarcado e o disco de ímãs de neodímio utilizado como carga

Para a medição das vibrações, foi necessário manter o motor em regime estacionário, isto é, com uma velocidade constante. Deste modo, foi utilizado o sistema de controle desenvolvido em [14] a fim de manter a velocidade fixa em 240 rpm. A escolha da velocidade levou em consideração um valor que a máquina, sob a falta

de uma de suas fases de alimentação, seria capaz de atingir, isto é, foi medida a máxima velocidade do teste com motor sob falha, pois os espectros seriam comparados, posteriormente, à mesma velocidade da máquina sem falha e sob falha. Os dados foram coletados durante aproximadamente 10 minutos.

Foi utilizado um código em C para a leitura das vibrações pelo acelerômetro, fornecido pelos autores de [13]. Além disso, vale ressaltar que foi preciso utilizar um código em Matlab para criar uma interface entre a placa KL25Z e o computador, cujas principais funções são de apresentar os sinais das vibrações no tempo, calcular seu espectro e salvar os dados em um arquivo de saída, com formato específico. Desta forma, foi possível processar os sinais através de um algoritmo programado no Matlab e calcular seu espectro em frequência através da Transformada Rápida de Fourier.

Os dados das vibrações são salvos em um arquivo de saída pela interface gerada pelo código dos autores de [13]. Vale ressaltar que foi necessário salvar os dados em arquivo quando a máquina já se apresentava em regime permanente para que a análise do espectro fosse facilitada.

No arquivo, são retratados os tempos de coleta de dados em uma frequência de amostragem de 817 Hz. Além disso, são definidos os três eixos x, y e z do acelerômetro. Os dados das vibrações da máquina sem falha são apresentados na Figura 4.

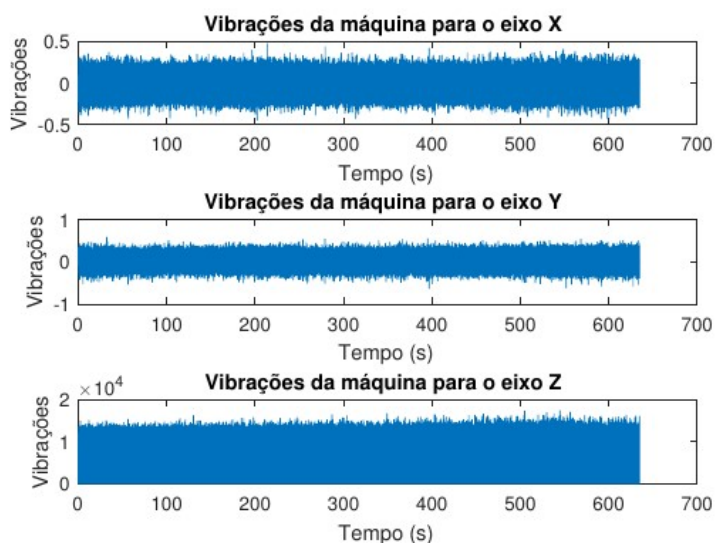


FIGURA 4 – Gráfico com as vibrações nos três eixos para a máquina sem falha

Para realizar a medição das vibrações da máquina com falha, a montagem experimental foi realizada da mesma forma das medições das vibrações sem falha, sendo a única diferença a desconexão de uma das fases de alimentação da máquina. Deste modo, a falha foi introduzida, os sinais foram coletados e processados por Matlab.

3.3 Processamento dos sinais e cálculo do espectro em frequência

Uma vez com os dados em formato Excel, foi necessário processá-los através do Matlab e calcular o espectro em frequência através da aplicação de Transformada Rápida de Fourier (FFT). Vale ressaltar que uma etapa inicial desta parte foi realizada antes da coleta dos dados com falha, para verificar a consistência do ensaio sem falha.

Nota-se que foi necessário separar os dados dos três eixos e tratá-los de forma separada. Além disso, para utilizar a FFT, optou-se por organizar os dados em forma de arranjo, isto é, um vetor de dados, ao invés da forma matricial.

O processamento e o cálculo do espectro para a máquina com falha foram realizados de forma análoga à parte anterior, uma vez que a única alteração foi no arquivo fonte dos sinais de vibração, que nesse caso, abrange o motor com a falta de uma das fases.

3.4 Estudo e treinamento da rede neural

Para se treinar a rede neural, foram estudados 4 tipos de carga: sem carga, carga leve, média e pesada. A carga foi introduzida através da aproximação de um disco com ímãs de neodímio à roda a que o motor está acoplado, conforme pode ser visto na figura 3. Em seguida, foram realizados ensaios com e sem falha para cada uma das condições de carga, totalizando 8 tipos de ensaios.

Após a coleta, os dados do tempo de cada ensaio foram divididos em 36 partes, com um total de 288 condições diferentes testadas. Das 288 condições, 50% (144) são utilizadas para treinamento, 25% (72) para teste e 25% (72) para validação, sendo a saída da rede definida como 1 no caso com falha e como 0 no caso sem falha. Vale ressaltar que o número de casos com falha e sem falha em cada um dos conjuntos é igual.

Em seguida, foi montada uma matriz de treinamento, cujos valores são os dados das 10 harmônicas dos espectros em frequência do sinal de vibração da máquina.

Uma motivação para o uso de rede neural para este problema é apresentada na Figura 5, em que são apresentadas as amplitudes das harmônicas dos espectros em frequência das vibrações no eixo X da máquina sem falha (primeiro gráfico) e com falha (segundo gráfico).

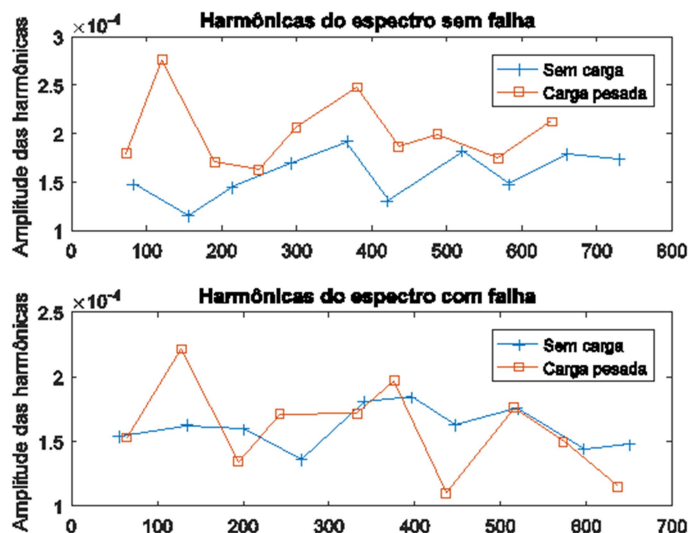


FIGURA 5 – Dados de vibração no eixo X para condições com e sem falha para uma condição sem carga e com carga pesada

Nota-se que, inicialmente, é impossível classificar a falha do sistema. A introdução de cargas deixa os sinais ainda mais difíceis de se classificar, conforme pôde ser visto na Figura 5. Deste modo, o uso de uma rede neural computacional se faz necessário.

4.0 – RESULTADOS E DISCUSSÃO

4.1 Vibrações da máquina

Para a máquina sem falha e com falha, foram obtidos os espectros nos eixos X, Y e Z, que estão representados na Figura 6.

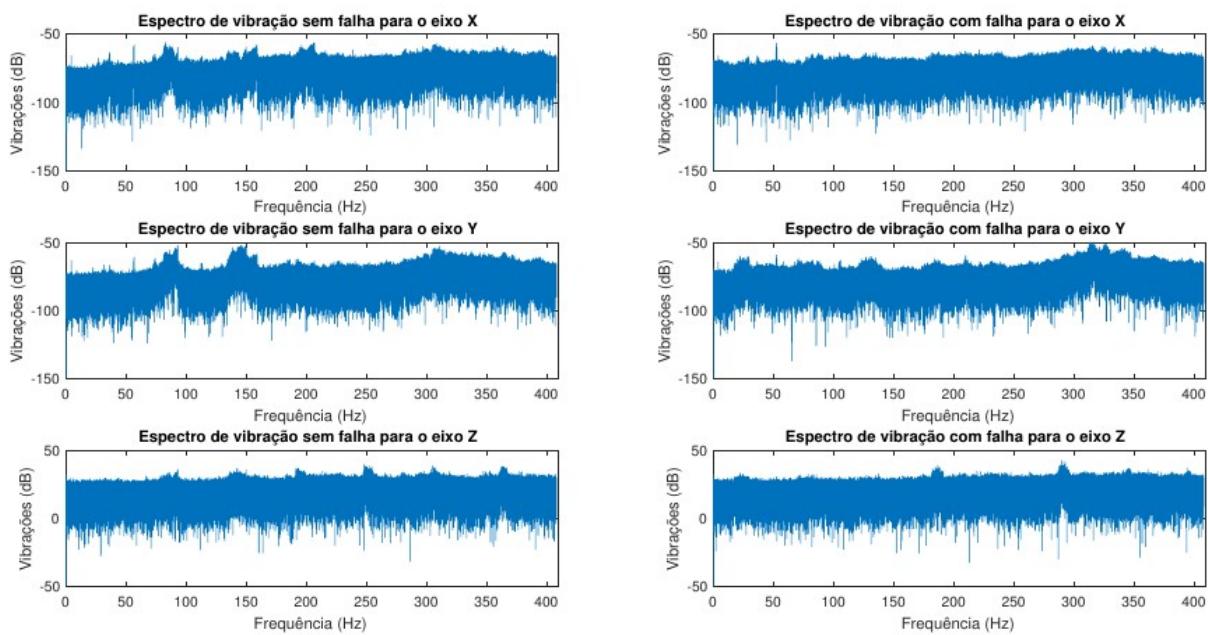


FIGURA 6 – Espectro em frequência das vibrações nos eixos X, Y e Z da máquina sem falha e com falha

Pela Figura 6, foi possível notar mais diretamente as diferenças entre os espectros da máquina com e sem falha, ou seja, se percebe um deslocamento do espectro com falha para a esquerda, isto é, tiveram-se as maiores raias em frequências menores.

4.2 Classificação pela Rede Neural

Os dados de vibrações foram coletados para os 3 eixos espaciais da máquina, isto é, eixos X, Y e Z. Inicialmente, foi considerado o treinamento da rede apenas para o eixo X, conforme é mostrado nas Figuras 7, 8 e 9.

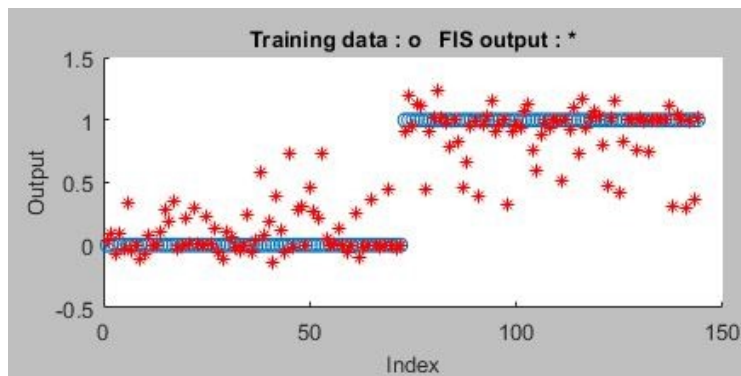


FIGURA 7 – Saída para dados de treino da rede neural treinada com dados do eixo X

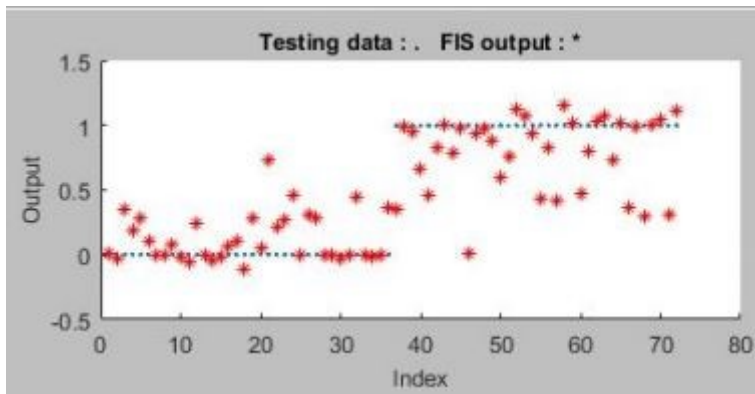


FIGURA 8 – Saída para dados de teste da rede neural treinada com dados do eixo X




FIGURA 9 – Saída para dados de validação da rede neural treinada com dados do eixo X

Pode-se notar que a saída da rede neural não foi adequada para classificar a falha na máquina, pois não se obteve um padrão de reconhecimento claro da falha. Desta forma, foram utilizados os dados dos eixos X e Y dos espectros de vibrações. O resultado é mostrado nas Figuras 10, 11 e 12.



FIGURA 10 – Saída para dados de treino da rede neural treinada com dados dos eixos X e Y




FIGURA 11 – Saída para dados de teste da rede neural treinada com dados dos eixos X e Y

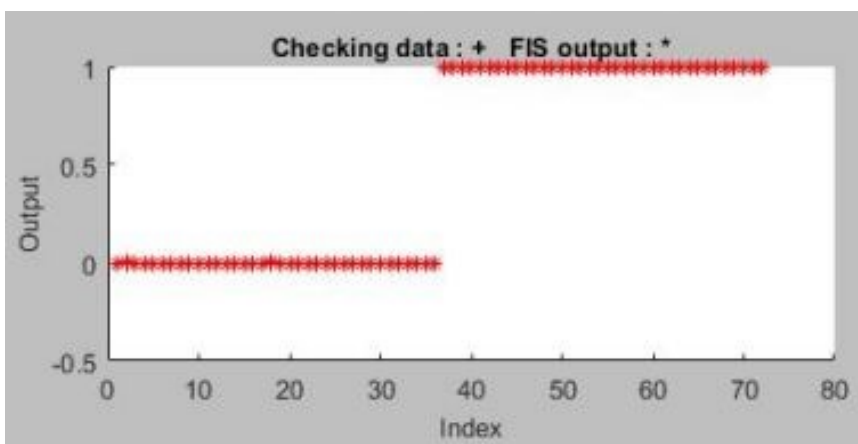


FIGURA 12 – Saída para dados de validação da rede neural treinada com dados dos eixos X e Y

É possível observar que, utilizando os dados dos eixos X e Y, foi possível classificar a falha de forma satisfatória, com reconhecimento claro da falha pela rede neural, pois a falta de uma das fases faz com que a mudança nas vibrações da máquina seja intensificada nos eixos no sentido radial (eixos X e Y) do motor, já que o movimento de rotação da máquina não se relaciona ao sentido axial (eixo Z). Nota-se que a saída da rede neural foi mais precisa para os dados de treinamento e de validação, isto é, alguns poucos pontos dos dados de teste apresentaram saída diferente do esperado, porém, dentro da tolerância, uma vez que o conjunto total foi de 72 conjuntos (25% das 288 condições testadas).

Na Tabela 2, são apresentadas as porcentagens dos conjuntos de pontos que ficaram fora do esperado para a saída da rede neural, em relação a cada conjunto de dados de treinamento:

Tabela 2 – Porcentagens dos conjuntos fora do esperado para a saída da rede neural

Tipo de dados	Eixo dos dados de treino	Quantidade fora do esperado	Quantidade total	Porcentagem de erro
Treino	X	74	144	51.4 %
Teste	X	48	72	66.7%
Validação	X	39	72	54.2 %
Treino	X e Y	0	144	0 %
Teste	X e Y	5	72	6.9 %
Validação	X e Y	0	72	0 %

É possível notar que, utilizando apenas os dados dos eixos X e Y, isto é, nas direções radiais, os resultados são suficientes para uma classificação com boa precisão. Os resultados do eixo X, analisado sozinho, não foram suficientes, uma vez que o movimento se relaciona ao plano perpendicular ao eixo da máquina, isto é,

eixos X e Y juntos. Além disso, não é esperado que os dados das vibrações no eixo Z, isto é, na direção axial, alterem a precisão da rede neural, conforme dito anteriormente.


5.0 - CONCLUSÃO

Neste informe foram apresentados os resultados da detecção de falta de uma das fases de alimentação de um motor BLDC, através de uma abordagem baseada em Rede Neural Artificial. Após os testes e os cálculos, foi observado que a rede neural treinada com os espectros em frequência dos sinais de vibrações apresentou uma classificação satisfatória da falha no sistema, utilizando dados de dois de seus eixos espaciais. Logo, é possível notar que o método empregado atendeu aos requisitos desejados, isto é, a abordagem baseada em redes neurais artificiais (análise do espectro em frequência das vibrações da máquina) foi capaz de classificar a falha de forma satisfatória. O aperfeiçoamento das técnicas de medição de qual das fases de alimentação será a causa da falha pode ser tema de trabalhos futuros.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) P. Sen, *Principles of Electric Machines and Power Electronics*, 2nd Ed. John Wiley and Sons, 1997.
- (2) S.T. Lee and J. Hur, "Detection Technique for Stator Inter-Turn Faults in BLDC Motors Based on Third-Harmonic Components of Line Currents", *IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS*, vol. 53, nº 1, 2016.
- (3) A. Usman, "A Review of Modeling, Analysis and Control Methods of Brushless DC Motors", *IEEE – International Conference on Computation of Power, Energy Information and Communication (ICCPEIC)*, 2016.
- (4) H. A. Toliyat, S. Nandi and X. Li, "Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review", *IEEE TRANSACTIONS ON ENERGY CONVERSION*, vol. 20, nº 4, 2005.
- (5) Y. Duan and H. Toliyat, "A Review of Condition Monitoring and Fault Diagnosis for Permanent Magnet Machines", *Power and Energy Society General Meeting*, 2012.
- (6) A. Boudiaf, A. Djebala, H. Bendjma, A. Balaska and A. Dahane, "A Summary of Vibration Analysis Techniques for Fault Detection and Diagnosis in Bearing", *8th International Conference on Modeling, Identification and Control (ICMIC-2016) Algiers, Algeria*, 2016.
- (7) H. N. Koti, J. Faiz and Z. Valipour, "Comprehensive review on inter-turn fault indexes in permanent magnet motors", *The Institution of Engineering and Technology*, vol. 11, nº 1, p. 142-156, 2016.
- (8) L. Xu and Y. Zhou, "Fault diagnosis for BLDCM system used FFT algorithm and support vector machines", *IEEE/CSAA International Conference on Aircraft Utility Systems (AUS), Beijing, China*, 2016.
- (9) M. Awadallah and M. Morcos, "Adaptive-Fuzzy-Based Stator-Winding Fault Diagnosis of PM Brushless DC Motor Drive by Monitoring Supply Current", *IEEE Power Engineering Review*, 2002.
- (10) P. Dobra, M. Dobra, D. Moga, V. I. Sita and R.A. Munteanu, "Model Based Fault Detection for Electrical Drives with BLDC motor", *IEEE International Conference on Automation, Quality and Testing, Robotics*, 2014.
- (11) S. Altug, M. Y. Chow and H. J. Trussell, "Fuzzy Inference Systems Implemented on Neural Architectures for Motor Fault Detection and Diagnosis", *IEEE Transactions on Industrial Electronics*, vol. 46, nº 6, 1999.
- (12) P. V. Goode and M. Y. Chow, "Using a Neural/Fuzzy System to Extract Heuristic Knowledge of Incipient Faults in Induction Motors: Part 1 - Methodology", *IEEE Transactions on Industrial Electronics*, vol. 42, nº 2, 1995.
- (13) L. A. S. Pedotti, R. M. Zago and F. Fruett, "Instrument based on MEMS accelerometer for vibration and unbalance analysis in rotating machines", *1st International Symposium on Instrumentation Systems, Circuits and Transducers (INSCIT)*, 2016.
- (14) R. D. da Silva, "Identificação de parâmetros e projeto do Sistema de controle de velocidade de motores de corrente contínua sem escovas BLDC", 2017, trabalho de Conclusão de Curso apresentado ao Instituto de Ciência e Tecnologia do Campus de Sorocaba, Universidade Estadual Paulista (UNESP), como parte dos requisitos para obtenção do grau de Bacharel em Engenharia de Controle e Automação.

7.0 - DADOS BIOGRÁFICOS



Victor Suguiiti Tanaka Graduação: Engenharia Elétrica (previsão 2019). Local: Unicamp – Faculdade de Engenharia Elétrica e de Computação
Experiência Profissional: Iniciação Científica FAPESP, publicação de artigo no ENAM 2018.



Prof. Dr. Mateus Giesbrecht. Possui graduação em Engenharia Elétrica pela Unicamp (2006), Mestrado em Engenharia Elétrica pela Unicamp (2008) e Doutorado em Engenharia Elétrica pela Unicamp (2013). Trabalhou por quase 10 anos como engenheiro eletricitista e coordenador de projetos de hidrogeradores na Andritz Hydro. Durante seus estudos, pesquisou a aplicação de técnicas de inteligência computacional nos problemas de identificação de sistemas e de realização de séries temporais. Desde 2015 é professor e pesquisador na Faculdade de Engenharia Elétrica e Computação da Unicamp, onde leciona disciplinas relacionadas a máquinas elétricas, tratamento de sinais multivariáveis, identificação de sistemas dinâmicos, realização de séries temporais e diagnóstico de falhas em sistemas dinâmicos.